



UNIVERSITAS ATMA JAYA YOGYAKARTA

CONVOLUTIONAL NEURAL NETWORK (CNN) UNTUK PENGKLASIFIKASIAN AKSARA JAWA

TEMA PENELITIAN UNIVERSITAS
Adaptif Terhadap Kebutuhan Global

TOPIK PENELITIAN UNIT
Pemodelan dan Simulasi

Ketua

Yulius Harjoseputro S.T., M.T.
(NPP.04.15.897/NIDN. 0510078901)

LAPORAN

PENELITIAN INTERNAL PERORANGAN
UNIVERSITAS ATMA JAYA YOGYAKARTA
FAKULTAS TEKNOLOGI INDUSTRI
PROGRAM STUDI TEKNIK INFORMATIKA
MEI 2018

HALAMAN PENGESAHAN
LAPORAN PENELITIAN INTERNAL : PERORANGAN

1	Judul Penelitian	Convolutional Neural Network Untuk Pengklasifikasian Aksara Jawa	
2	Kategori Penelitian	A. Penelitian diorientasikan pada penerbitan artikel jurnal ilmiah	
3	Tema Penelitian Universitas	Adaptif Terhadap Kebutuhan Global	
4	Topik Penelitian Unit	<i>Pemodelan dan Simulasi</i>	
5	Bebas SKS Penelitian	(4) sks	Berlaku semester Ganjil 2017/2018
IDENTITAS PENELITI			
6	Nama Peneliti	Yulius Harjoseputro S.T., M.T.	
	Jabatan/Golongan	Asisten Ahli / III-B	
	NIP / NIDN	04.15.897	0510078901
	Bidang Keahlian	Teknik Informatika	
	Unit/ Fakultas/ Jurusan	Fakultas	Jurusan/ Program Studi
		Teknologi Industri	Teknik Informatika
	Alamat Rumah	Perumahan Agatama Residence Purwomartani No 10 Yogyakarta	
	No.Telp/Faks/E-mail Peneliti	085659849830	E-mail : yulius.harjoseputro@staff.uajy.ac.id
	Asisten Peneliti	Kefin Pudi Danukusumo, ST. (Alumni Teknik Informatika angkatan 2013)	
7.	Lokasi Penelitian	Universitas Atma Jaya Yogyakarta	
	Waktu Penelitian	Agustus 2017 – Januari 2018	
8.	Dana yang diusulkan	Dana UAJY	
		Rp.12.500.000	
	Jumlah Total	Rp.12.500.000	
9.	terbilang	Dua belas juta lima ratus ribu rupiah	
10.	Spesifikasi <i>outcome</i> penelitian	Makalah ilmiah yang dipublikasi di Internasional Conference	

Yogyakarta, 18 Mei 2018



Mengetahui,
Dekan Fakultas Teknologi Industri,

Dr. A. Teguh Siswantoro

NPP. 09.93.464/NIDN.0521115901

Pengusul,

Yulius Harjoseputro, S.T., M.T.

NPP.04.15.897/NIDN. 0510078901

Mengetahui dan Menyetujui,

Ketua LPPM



Dr. I Putu Sugiarta Sanjaya, SE., M.Si., Ak., CA.

NPP: 12.94.528/NIDN: 0524107001

RINGKASAN

Computer Vision memiliki permasalahan yang penting di dalamnya adalah salah satunya yang berkaitan dengan klasifikasi citra, dimana pada dasarnya klasifikasi citra biasa digunakan untuk mendeteksi suatu objek di dalam suatu citra. Proses klasifikasi citra ini dianggap tidak mudah untuk dilakukan oleh komputer, oleh karena itu untuk mempermudah komputer dalam proses pengklasifikasian citra maka beberapa peneliti menggunakan beberapa metode, diantaranya yang paling klasik digunakan adalah metode jaringan syaraf tiruan. Akan tetapi dalam penggunaan metode tersebut masih terdapat batasannya, diantaranya jumlah neuron yang digunakan sehingga hasil yang digunakan untuk klasifikasi citra masih belum optimal. Sementara itu salah satu metode yang sangat populer belakangan ini untuk menangani keterbatasan dari metode yang sebelumnya adalah dengan menggunakan teknik dari *Deep Learning* yakni menggunakan metode *Convolutional Neural Network (CNN)*.

Berdasarkan hasil penelitian yang telah dilakukan dengan metode CNN dalam hal ini menghasilkan tingkat akurasi untuk trainingnya adalah sebesar 90% dengan waktu training menggunakan GPU sebesar 409.25 detik. Lalu tingkat akurasi untuk tes pengklasifikasian aksara jawa yang cukup baik yakni sebesar 85%, dimana ini merupakan modal yang sangat baik untuk dikembangkan menjadi sebuah sistem yang dapat mengenali rangkaian aksara jawa.

Kata Kunci: Computer Vision, Neuron, Deep Learning, Convolutional Neural Network

PRAKATA

Puji syukur kepada Tuhan Yang Maha Esa penulis panjatkan karena atas anugerah, berkat dan rahmat-Nya, penulis dapat menyelesaikan penelitian yang berjudul “*Convolutional Neural Network Untuk Pengklasifikasian Aksara Jawa*”. Laporan ini penulis susun untuk memenuhi kewajiban hibah Penelitian Internal Perorangan Monodisiplin Universitas Atma Jaya Yogyakarta.

Penulis mengucapkan terima kasih kepada Lembaga Penelitian dan Pengabdian pada Masyarakat (LPPM) Universitas Atma Jaya Yogyakarta yang telah membantu selama proses seleksi, monitoring dan evaluasi penelitian ini. Tidak lupa juga penulis mengucapkan banyak terima kasih kepada civitas akademik Universitas Atma Jaya Yogyakarta yang telah membantu penulis dalam penelitian ini, dan pihak-pihak lain yang turut membantu penyusunan laporan penelitian ini sehingga dapat memberikan manfaat bagi pembaca.

Akhir kata, penulis bersedia menerima baik kritik maupun saran yang dapat membangun baik penulis maupun pembaca agar dapat berkarya dengan lebih baik lagi. Selain itu penulis meminta maaf jika terdapat kekurangan dalam laporan ini. Semoga penelitian ini bermanfaat. Terima kasih.

Yogyakarta, 18 Mei 2018

Yulius Harjoseputro, S.T., M.T

DAFTAR ISI

	Halaman
JUDUL PENELITIAN	i
HALAMAN PENGESAHAN	ii
RINGKASAN	iii
PRAKATA	iv
DAFTAR ISI	v
BAB I. PENDAHULUAN	1
BAB II. TINJAUAN PUSTAKA DAN DASAR TEORI	3
2.1 Tinjauan Pustaka	3
2.2 Dasar Teori	5
2.2.1 Klasifikasi Citra	5
2.2.2 Metode Deep Learning.....	5
2.2.3 Metode Convolutional Neural Network	7
BAB III. TUJUAN DAN MANFAAT PENELITIAN.....	10
3.1 Tujuan Penelitian	10
3.2 Manfaat Penelitian	10
BAB IV. METODE PENELITIAN	11
4.1 Bahan Penelitian.....	11
4.2 Jalannya Penelitian.....	12
4.3 Lokasi Penelitian.....	13
4.4 Peralatan Penelitian.....	13
BAB V. HASIL DAN LUARAN YANG DICAPAI.....	14
5.1 Hasil Analisis Penelitian Seluruh Kelompok.....	14
5.2 Hasil Analisis Penelitian Per Kelompok.....	17
BAB VI. KESIMPULAN DAN SARAN.....	22
6.1 Kesimpulan.....	22
6.2 Saran.....	22
DAFTAR PUSTAKA	23

BAB I. PENDAHULUAN

Salah satu permasalahan yang terpenting di dalam bidang *Computer Vision* adalah klasifikasi citra. Dimana klasifikasi citra merupakan proses untuk mendeteksi objek dari suatu citra yang ada. Salah satu teknik yang populer dan banyak digunakan untuk klasifikasi citra adalah dengan menggunakan metode Jaringan Syaraf Tiruan (JST). Dimana metode JST ini dapat mengubah struktur yang dimiliki untuk memecahkan masalah menggunakan informasi internal maupun informasi eksternal, atau dengan definisi lain teknik ini merupakan teknik yang dapat belajar dari pengalaman yang telah dilakukan sebelumnya. Teknik JST ini memiliki beberapa lapisan yang disebut dengan Multi Layer Perceptron, dimana konsepnya adalah menghubungkan secara penuh antar neuronnya sehingga memiliki kemampuan klasifikasi yang powerful.

Akan tetapi terdapat permasalahan ketika menggunakan metode JST untuk pengklasifikasian yang menggunakan input berupa gambar. Karena untuk melakukan pengklasifikasian yang menggunakan input berupa gambar tersebut membutuhkan beberapa proses yang harus dilakukan, diantaranya preprocessing, proses segmentasi dan proses ekstraksi fitur. Dari beberapa proses yang harus dilakukan tersebut menyebabkan memiliki banyak parameter bebas atau yang sering dikatakan dengan informasi yang berlebihan sehingga akan menyebabkan proses klasifikasi kurang maksimal.

Berdasarkan atas permasalahan yang terdapat dalam metode Jaringan Syaraf Tiruan tersebutlah maka munculah salah satu teknik dari *Deep Learning* yakni metode *Convolutional Neural Network*. Metode ini digunakan agar dapat mengurangi parameter bebas yang dihasilkan dari proses yang menggunakan metode JST tersebut.

Selain itu salah satu hal yang membuat *Computer Vision* berkembang dengan sangat pesat saat ini adalah teknik yang terdapat pada metode *Deep Learning* atau biasa disebut *Deep Neural Network*, terutama *Convolutional Neural Network (CNN)* (Krizhevsky et al., 2012). Metode-metode tersebut merupakan salah satu dari metode yang tercakup di dalam kategori *machine intelligence*. CNN telah dapat membuat perkembangan yang sangat signifikan dalam masalah *image classification*, *object detection*, *object localization*, serta *image segmentation*.

Hal yang membuat metode CNN sangat populer digunakan untuk masalah-masalah Computer Vision terlihat dengan adanya kompetisi *ImageNet Large Scale Visual Recognition Challenge* (ILSVRC) (Russakovsky et al., 2015). Kompetisi tahunan ini merupakan satu hal yang sangat penting dalam memajukan penelitian-penelitian di bidang Computer Vision. Tahun demi tahun, metode *state of the art* bermunculan dalam rangka untuk memenangkan kompetisi ini, contohnya AlexNet (Krizhevsky et al., 2012), GoogLeNet (Szegedy et al., 2015), dan ResNet (He et al., 2015). Pada klasifikasi citra, AlexNet dapat meningkatkan akurasi dari metode tradisional yang digunakan oleh peringkat kedua dari kompetisi tersebut sebesar lebih dari 10%. Bagi kompetisi ILSVRC yang mencakup 1000 kategori image, metode *baseline* hanya dapat mendapatkan akurasi sebesar 0,1%. Hal tersebut membuat hasil yang diraih oleh AlexNet menjadikan CNN sebagai metode *state of the art* dan secara *de facto* menjadi metode yang selalu dipilih untuk menjawab masalah-masalah di Computer Vision.

Akan tetapi meskipun memiliki kelebihan, CNN tidak luput pula dari kekurangannya yakni sama halnya metode-metode Deep Learning yang lain adalah untuk membangun dan melakukan *training* pada metode tersebut sangatlah mahal, baik dari sisi waktu maupun beban komputasi. Bahkan dengan adanya Graphic Processing Unit (GPU), yang dapat mempercepat proses paralel, untuk melakukan *training* pada CNN modern terhadap dataset berskala besar, misalnya ImageNet tetaplah relatif mahal. Contohnya, untuk melakukan training pada VGGNet dengan 19 *layers* terhadap dataset ImageNet, dibutuhkan waktu 2-3 minggu pada sistem dengan 4 GPU (Simonyan et al., 2014).

Berdasarkan dengan tingginya *computational cost* dari CNN membuat metode-metode klasik seperti metode jaringan syaraf tiruan masih tetap memiliki daya tarik karena metode-metode tersebut relatif jauh lebih cepat dibandingkan dengan metode Deep Learning.

Maka dari itu, dalam penelitian ini, akan dibangun sebuah aplikasi yang digunakan untuk mengklasifikasi citra aksara Jawa menggunakan *Convolutional Neural Network* (CNN). Dengan harapan didapatkan performa yang jauh lebih baik dibandingkan dengan metode yang sudah sangat populer digunakan yakni metode Jaringan Syaraf Tiruan (JST).

BAB II. TINJAUAN PUSTAKA DAN DASAR TEORI

2.1. Tinjauan Pustaka

Salah satu bidang di ilmu komputer yang berkembang dengan pesat adalah Computer Vision. Terbukti dengan adanya beberapa kompetisi tahunan seputar Computer Vision diantaranya Large Scale Visual Recognition Challenge (ILSVRC) (Russakovsky et al., 2015), PASCAL Visual Object Classes (VOC) (Everingham et al., 2010), dan Microsoft Common Objects in Context (MSCOCO) (Lin et al., 2014).

Dengan adanya kompetisi tersebut, setiap tahunnya bermunculan metode-metode *state of the art* di bidang *image classification*, *object detection*, dan *image segmentation*. Dalam beberapa tahun terakhir, metode Deep Learning berhasil meningkatkan performa di kompetisi-kompetisi tersebut, jauh di atas metode *state of the art* sebelumnya. Awal kesuksesan Deep Learning dimulai dengan AlexNet, metode *image classification* berbasis Convolutional Neural Network (CNN), yang berhasil memenangkan ILSVRC 2012 dengan *error rate* sebesar 15.3% dibandingkan dengan posisi kedua sebesar 26.2% (Krizhevsky et al., 2012).

Penggunaan teknik *Deep Learning* dengan metode *Convolutional Neural Network* ini pertama kali berhasil diaplikasikan yakni oleh Yann LeCun pada tahun 1998 (LeCun, Bottou, Bengio, & Haffner, 1998). Pada penelitian ini, Yann LeCun mengemukakan metode CNN untuk mengenal tulisan tangan untuk keperluan pembacaan dokumen. Hasil yang didapat dari penelitian tersebut menunjukkan akurasi yang cukup tinggi hingga mencapai test error hanya sebesar 1,7%.

Untuk penerapan metode *Convolutional Neural Network* ini dapat dikembangkan dari sisi arsitektur dan banyaknya penggunaan lapisan pada jaringan. Penggunaan arsitektur yang benar akan sangat baik untuk klasifikasi citra dalam berbagai macam kategori. Contohnya seperti pada dataset ImageNet yang memiliki sebanyak 1000 kategori. Pada tahun 2012 teknik *Deep Learning* dengan metode CNN dipopulerkan dengan asritektur AlexNet yang diuji dengan dataset ImageNet (Krizhevsky et al., 2012). Arsitektur yang dibuat oleh Alex Krizhevsky menunjukan hasil yang sangat signifikan pada testing set

dengan test error sebesar 17%. Hasil tersebut dinilai sudah sangat luar biasa karena citra pada dataset yang digunakan sangatlah kompleks dan banyak.

Selain itu Simonyan et al., (2014) melakukan penelitian yang serupa yakni menggunakan lapisan konvolusi sebanyak 16 hingga 19 lapisan. Dari hasil penelitian tersebut, menunjukkan performa yang sangat baik dengan akurasi yang lebih besar dibanding dengan arsitektur yang sudah dikemukakan sebelumnya. Hal tersebut membuktikan bahwa kedalaman jaringan itu merupakan komponen yang tidak kalah penting juga untuk mendukung kinerja yang baik dalam pengenalan citra. Dan dapat dikatakan bahwa lebih dalam sebuah arsitektur jaringan maka akan lebih banyak lapisan yang digunakan.

Perbaikan Model AlexNet pun dilakukan oleh Fergus & Zeiler (2014) dengan mengubah arsitektur *hyperparameter*, terutama dengan memperluas ukuran lapisan konvolusi di tengah susunan model dan membuat ukuran filter pada lapisan pertama lebih kecil. Dari hasil penelitian tersebut menghasilkan model yang baik untuk banyak dataset lain ketika klasifikasi *Softmax* dilatih ulang dengan data yang baru. Hal ini sangat meyakinkan mengingat hasil yang diberikan mengalahkan hasil riset sebelumnya yang dilakukan untuk dataset Caltech-101 dan Caltech-256.

Pengembangan model AlexNet juga dilakukan oleh Szegedy et al. (2015). Dimana pada penelitian tersebut, kontribusi yang dilakukan ialah mengurangi jumlah parameter yang ada di jaringan yakni hanya berkisar 4 juta parameter, jauh lebih baik dibanding pendahulunya yakni AlexNet dengan 60 juta parameter. Penelitian ini juga menghasilkan terobosan baru dengan menggunakan model GoogLeNet. Penggunaan parameter yang tepat antar lapisan dalam model CNN pastinya dapat mengurangi beban komputasi pada saat pelatihan.

Pada penelitian yang akan dilakukan ini, model CNN yang digunakan tidak memerlukan banyak lapisan guna untuk menghemat waktu pembelajaran. Kesederhanaan arsitektur CNN yang digunakan sudah cukup untuk kasus klasifikasi citra dengan dataset yang dapat terbilang kecil, terlebih kategori untuk klasifikasi hanya sedikit. Seditkitnya jumlah data yang akan dipelajari dapat menghasilkan akurasi yang kurang memuaskan, untuk itu ada beberapa hal yang harus dilakukan demi mendapat hasil yang cukup baik.

Teknik ini sangat mudah diimplementasikan pada model CNN dan akan berdampak pada performa model dalam melatih serta mengurangi *overfitting* (Srivastava, et.al., 2014).

Hasil pengujian pada penelitian ini juga akan dibandingkan berdasarkan jumlah *epochs* yang digunakan dan setelah itu jumlah *epochs* yang optimal akan diambil dilihat dari sisi kecepatan dan ketepatan model dalam mempelajari data berkaitan dengan dalam aksara jawa.

2.2. Dasar Teori

2.2.1 Klasifikasi Citra

Klasifikasi citra merupakan salah satu dari masalah yang tercakup di dalam bidang Computer Vision. Selain itu klasifikasi citra merupakan sebuah pekerjaan dimana memasukkan sebuah citra dan menetakannya ke sebuah kategori. Ini adalah salah satu permasalahan dalam *Computer Vision* yang dapat disederhanakan dan memiliki berbagai macam aplikasinya. Salah satu aplikasi dalam klasifikasi citra adalah pengklasifikasian nama tempat pada suatu citra.

Dalam klasifikasi yang terawasi, setiap masukkan citra pada *training set* diberi label. Saat klasifikasi, label tersebut akan menjadi perbandingan dengan hasil hipotesis yang diberikan oleh model pembelajaran dan akan menghasilkan nilai error. Klasifikasi yang terawasi bisa sangat efektif dan akurat dalam mengklasifikasikan citra tempat maupun objek lainnya. Banyak metode dan algoritma yang dapat mendukung proses klasifikasi yang terawasi terutama dengan teknik *Deep Learning*.

2.2.2 Metode Deep Learning

Machine Learning merupakan metode untuk yang digunakan mempelajari data sehingga dapat melakukan hal-hal yang berguna pada data baru yang belum pernah ditemui. Lain halnya dengan pemrograman biasa yang diharuskan untuk secara eksplisit untuk memberikan aturan kepada komputer ketika ingin melakukan aksi, Machine Learning

mempelajari aturan tersebut secara implisit dan otomatis dari contoh-contoh data yang sudah ada.

Machine Learning adalah salah satu teknologi yang populer dan banyak digunakan belakangan ini. Hampir di semua sisi dunia digital yang digunakan sehari-hari menggunakan Machine Learning. Penerapan Machine Learning ini biasa terdapat pada aplikasi sehari-hari yang sering kita gunakan, diantaranya Google Translate, Google Now, Google Maps, Youtube, Siri, dan lain-lain.

Machine Learning memiliki kekurangan yang konvensional yakni mahalnya proses representasi data. *Feature engineering* dari data harus dilakukan secara hati-hati dan tak jarang, dibutuhkan *domain expert* dalam prosesnya agar didapatkan hasil yang maksimal. Hal ini membuat proses pengolahan data tidak praktis dalam skala besar.

Dalam 10 tahun belakangan ini, muncul teknik-teknik baru dalam bidang Machine Learning yang memungkinkan bagi sistem untuk mempelajari data representasi dari data mentah secara otomatis. Teknik baru dalam bidang Machine Learning tersebut disebut sebagai Deep Learning.

Deep Learning merupakan salah satu bidang dari *Machine Learning* yang memanfaatkan jaringan syaraf tiruan untuk implementasi permasalahan dengan dataset yang besar. Teknik *Deep Learning* memberikan arsitektur yang sangat kuat untuk *Supervised Learning*. Dengan menambahkan lebih banyak lapisan maka model pembelajaran tersebut bisa mewakili data citra berlabel dengan lebih baik. Sebagai contohnya, pada *input layer*, data masih berupa data mentah, misalnya piksel warna pada image. Pada *layer* pertama, data direpresentasikan sebagai bagian-bagian image yang paling sederhana, misalkan garis. Pada *layer* selanjutnya, data direpresentasikan sebagai bentuk sederhana yang merupakan komposisi dari garis. Pada *layer* selanjutnya, representasi tersebut semakin abstrak dan kompleks. Hal ini membuat fungsi yang sangat kompleks dapat dipelajari dari data.

Beberapa aplikasi Deep Learning telah berhasil memecahkan rekor dari berbagai macam permasalahan hanya dalam beberapa tahun terakhir ini. Contohnya, Deep Convolutional Neural Network (CNN) berhasil mengalahkan metode Machine Learning konvensional pada ImageNet ILSVRC 2012 dengan margin yang besar. CNN sangatlah sukses untuk menyelesaikan permasalahan *image classification* sehingga pada tahun-tahun

berikutnya pada kompetisi ImageNet ILSVRC, semua kompetitor menggunakan metode Deep Learning. Deep Learning juga berhasil membuat perkembangan yang signifikan dalam bidang *language modelling*, *speech recognition*, dan interaksi komputer dengan manusia.

Deep Learning memiliki dua metode yang paling populer digunakan adalah Convolutional Neural Network (CNN) dan Recurrent Neural Network (RNN). CNN biasa digunakan dalam proses-proses yang berhubungan dengan *image*. Sedangkan RNN biasa digunakan dalam proses-proses yang berhubungan dengan data yang sekuensial, misalnya *speech recognition*, Natural Language Processing (NLP), dan *machine translation*.

Beberapa faktor yang menyebabkan Deep Learning menjadi populer dalam beberapa tahun belakangan ini. Alasan yang pertama karena kemampuan komputasi yang maju dengan pesat. Permasalahan utama dari Deep Learning ialah dengan semakin besarnya suatu Neural Network, maka akan semakin besar juga beban komputasi yang diperlukan. Hal ini teratasi dengan adanya GPU yang membuat training Deep Neural Network dapat diselesaikan dalam jangka waktu yang memungkinkan. Alasan yang kedua, karena jumlah data yang tersedia. Meskipun Neural Network telah ada sejak tahun 80an, namun jumlah data yang sedikit menjadi kendala. Deep Neural Network memiliki jumlah parameter yang sangat besar. Dengan jumlah data yang sedikit, Deep Neural Network akan mudah mengalami *overfitting*. Neural Network yang mengalami *overfitting* tidaklah dapat mempelajari data dengan efektif. Dalam beberapa tahun terakhir, data tersedia dalam jumlah yang sangat besar. Hal tersebutlah yang membuat *training* Deep Neural Network menjadi memungkinkan.

2.2.3 Metode Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan metode yang tercakup di dalam kelas *Feed Forward Neural Network* yang terinspirasi dari *visual cortex* dari otak dan dikhususkan untuk memproses data yang memiliki struktur grid. CNN mempunyai beberapa jenis layer yang dapat digunakan, yaitu *subsampling layer*, *convolutional layer*, *loss layer* dan *fully connected layer*.

Subsampling layer biasa digunakan untuk mengurangi dimensi yang berasal dari input. Tujuannya adalah untuk mengurangi jumlah parameter yang dibutuhkan dalam CNN dan juga untuk membuat CNN invarian terhadap perubahan kecil di dalam suatu citra.

Convolution layer bekerja dengan meniru sifat-sifat dari *visual cortex* otak dan mempelajari filter-filter dari *input image*. Layer ini disebut dengan *convolutional layer* karena operasi yang dilakukan adalah *convolution* antara filter dengan *input image*. Filter yang dipelajari pada layer ini dapat berbentuk berbagai macam, misalnya jika digunakan untuk mempelajari *image*, maka filter tersebut mungkin mempelajari untuk melakukan *edge detection*.

Loss layer merupakan *output layer* dari CNN. Dalam klasifikasi citra, jika terdapat dua kelas klasifikasi, maka *loss layer* yang digunakan adalah *sigmoid loss*, di mana *output* dari *layer* tersebut mengikuti distribusi Bernoulli. Pada klasifikasi citra dengan banyak kelas, maka digunakan distribusi Categorical, yang biasa disebut dengan *softmax layer*. Pada permasalahan lain, dapat digunakan *loss layer* yang sesuai. Seperti pada permasalahan *regression*, dapat digunakan *L2-loss layer* yang mengkalkulasi perbedaan antara *input* dengan *output* menurut fungsi *L2-norm*.

Fully connected layer merupakan layer yang biasa ditemukan pada Neural Network biasa. Berbeda dengan *convolutional layer*, *fully connected layer* tidak menggunakan operasi *convolution* untuk mendapatkan keluaran dari layer tersebut, tetapi menggunakan perkalian matriks. Dengan penggunaan operasi tersebut, maka setiap input *node* akan dihubungkan dengan *hidden node* yang ada di dalam layer, sehingga layer ini disebut sebagai *fully connected layer*.

Walaupun inti utama dari CNN adalah *layer* di atas, karena pesatnya perkembangan di bidang ini, muncul teknik-teknik baru yang dapat membuat *training* CNN menjadi lebih efisien dan efektif. Beberapa contoh perkembangan tersebut adalah Rectified Linear Unit (ReLU), Dropout, dan Batch Normalization.

CNN efektif dalam menyelesaikan masalah-masalah yang berkenaan dengan *image* sehingga hampir seluruh sistem Machine Learning yang berhubungan dengan *image* saat ini berbasis CNN. Riset pada CNN juga terus berkembang, terbukti dengan selalu terpecahkannya rekor pada ILSVRC tahun demi tahun sejak tahun 2012.

Berbagai macam varian dari CNN juga telah banyak dikembangkan. Beberapa contoh dari varian-varian tersebut ialah AlexNet (Krizhevsky et al., 2012), VGGNet (Simonyan et al., 2014), GoogLeNet (Szegedy et al., 2015), dan ResNet (He et al., 2015)



BAB III. TUJUAN DAN MANFAAT PENELITIAN

3.1. Tujuan Penelitian

Tujuan dari penelitian ini diantaranya adalah untuk mengembangkan aplikasi untuk klasifikasi citra aksara jawa dengan menggunakan *Convolutional Neural Network (CNN)*. Selain itu peneliti dalam melakukan penelitian ini juga memiliki tujuan yakni untuk menganalisis kinerja dari pelatihan model menggunakan GPU serta menganalisis akurasi dalam mengklasifikasikan citra aksara jawa menggunakan metode CNN.

3.1. Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat yaitu:

a. Manfaat Teoritis

Secara teoritis, penelitian ini diharapkan dapat mengetahui pengaruh penggunaan metode Convolutional Neural Network (CNN) khususnya dalam mengklasifikasikan aksara jawa.

b. Manfaat Praktis

Penelitian ini diharapkan dapat memberikan manfaat praktis terhadap peneliti agar penelitian ini dapat menjadi sarana dan referensi dalam menerapkan ilmu serta pengalaman yang didapatkan sebagai tenaga pengajar dan untuk menambah wawasan dan ilmu pengetahuan.

BAB IV. METODE PENELITIAN

4.1. Bahan Penelitian


Di dalam penelitian ini terdapat sebuah dataset yang berisi data citra pelatihan serta pengujian dan juga citra-citra candi di luar dataset sebagai data untuk klasifikasi. Berikut rincian data untuk bahan penelitian:

1. Dataset Aksara Jawa

Dataset ini berisikan citra dari semua aksara jawa yang ada yakni ada 20 kategori aksara jawa, diantaranya HA, NA, CA, RA, KA, DA, TA, SA, WA, LA, PA, DHA, JA, YA, NYA, MA, GA, BA, THA, NGA, yang masing- masing berukuran 32 X 32 piksel. Aksara jawa yang dimaksudkan tidak termasuk dengan pasangannya . Dataset ini secara keseluruhan memiliki 1000 citra pelatihan dan 100 citra pengujian yang dikumpulkan melalui repositori yang ada pada website. Berikut gambaran citra pada dataset aksara jawa untuk setiap kategorinya yang pada gambaran ini hanya diwakilkan 5 kategori:

a. Kategori 1 (HA)

Pada kategori 1 ini yakni HA, terdapat 50 citra pelatihan dan 5 citra pengujian



Gambar 1. Contoh Beberapa Citra Aksara Jawa HA

Sumber : Google.com

b. Kategori 2 (NA)

Pada kategori 2 ini yakni NA, terdapat 50 citra pelatihan dan 5 citra pengujian



Gambar 2. Contoh Beberapa Citra Aksara Jawa NA

Sumber : Google.com

c. Kategori 3 (CA)

Pada kategori 3 ini yakni CA, terdapat 50 citra pelatihan dan 5 citra pengujian




Gambar 3. Contoh Beberapa Citra Aksara Jawa CA

Sumber : Google.com

d. Kategori 4 (RA)

Pada kategori 4 ini yakni RA, terdapat 50 citra pelatihan dan 5 citra pengujian



Gambar 4. Contoh Beberapa Citra Aksara Jawa RA

Sumber : Google.com

e. Kategori 4 (KA)

Pada kategori 5 ini yakni KA, terdapat 50 citra pelatihan dan 5 citra pengujian



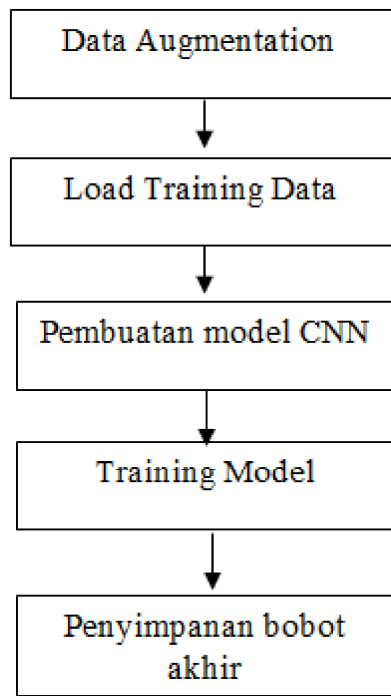
Gambar 5. Contoh Beberapa Citra Aksara Jawa KA

Sumber : Google.com


Selain 5 kategori yang disebutkan diatas,masih ada 15 kategori yang lainnya diantaranya adalah kategori DA, TA, SA, WA, LA, PA, DHA, JA, YA, NYA, MA, GA, BA, THA, NGA yang gambaranya sama dengan contoh dari gambar 1 sampai gambar 5.

4.2 Jalannya Penelitian

Penelitian yang dibuat ini sebagai penelitian dengan kaji pustaka dan pembangunan perangkat lunak dengan perbandingan data sekunder sebagai validasi. Secara garis besar jalannya penelitian ada 2 tahap besar yang dilakukan yakni pelatihan dan pengujian yang dijelaskan seperti berikut:



Gambar 6. Alur Tahapan Pelatihan



Gambar 7. Alur Tahapan Pengujian

4.3 Lokasi Penelitian

Penelitian dilakukan pada di laboratorium Struktur Data Fakultas Teknologi Industri Laboratorium memiliki peralatan uji seperti komputer dengan spesifikasi yang cukup tinggi dan software yang dibutuhkan.

4.4. Peralatan Penelitian

Peralatan yang digunakan untuk pengembangan perangkat lunak adalah seperti berikut:

- a. Komputer dengan spesifikasi processor I7, ram 16 GB, graphic/VGA Card NVidia GeForce GTX 660 TI dan NVidia GeForce GTX 670 dan hardisk 1 TB. Performance kecepatan program untuk setiap VGA card akan dibandingkan.
- b. Perangkat lunak yang digunakan untuk mendukung pengembangan:
 - 1) Sistem operasi Linux Ubuntu
 - 2) Program TensorFlows untuk membangun perangkat lunak utama

BAB V. HASIL DAN LUARAN YANG DICAPAI

5.1 Hasil Analisis Penelitian Seluruh Kelompok

Dalam penelitian ini, menggunakan dataset ini berisikan citra dari semua aksara jawa yang ada yakni ada 20 kategori aksara jawa, diantaranya HA, NA, CA, RA, KA, DA, TA, SA, WA, LA, PA, DHA, JA, YA, NYA, MA, GA, BA, THA, NGA, yang masing- masing berukuran 32 X 32 piksel. Dengan menggunakan 1000 citra pelatihan dan 100 citra pengujian. Hasil pengujian yang telah dilakukan dengan menggunakan 100 citra pengujian, disajikan dalam tabel 1 berikut ini :

No	Nama Citra Uji	Hasil Prediksi	Hasil Yang Sebenarnya
1	ba1.jpg	ba	ba
2	ba2.jpg	ba	ba
3	ba3.jpg	ba	ba
4	ba4.jpg	ba	ba
5	ba5.jpg	ba	ba
6	ca1.jpg	ca	ca
7	ca2.jpg	ca	ca
8	ca3.jpg	ca	ca
9	ca4.jpg	ca	ca
10	ca5.jpg	ca	ca
11	da1.jpg	na*	da
12	da2.jpg	na*	da
13	da3.jpg	da	da
14	da4.jpg	na*	da
15	da5.jpg	na*	da
16	dha1.jpg	dha	dha
17	dha2.jpg	dha	dha
18	dha3.jpg	dha	dha
19	dha4.jpg	dha	dha
20	dha5.jpg	dha	dha
21	ga1.jpg	ga	ga
22	ga2.jpg	pa*	ga
23	ga3.jpg	ga	ga
24	ga4.jpg	ga	ga
25	ga5.jpg	pa*	ga
26	ha1.jpg	ha	ha
27	ha2.jpg	ha	ha
28	ha3.jpg	ha	ha


29	ha4.jpg	ha	ha
30	ha5.jpg	ha	ha
31	ja1.jpg	pa*	ja
32	ja2.jpg	ja	ja
33	ja3.jpg	ja	ja
34	ja4.jpg	ja	ja
35	ja5.jpg	ja	ja
36	ka1.jpg	ka	ka
37	ka2.jpg	nga*	ka
38	ka3.jpg	ka	ka
39	ka4.jpg	ka	ka
40	ka5.jpg	nga*	ka
41	la1.jpg	la	la
42	la2.jpg	la	la
43	la3.jpg	la	la
44	la4.jpg	la	la
45	la5.jpg	la	la
46	ma1.jpg	ma	ma
47	ma2.jpg	ma	ma
48	ma3.jpg	ma	ma
49	ma4.jpg	ma	ma
50	ma5.jpg	ma	ma
51	na1.jpg	na	na
52	na2.jpg	na	na
53	na3.jpg	na	na
54	na4.jpg	na	na
55	na5.jpg	na	na
56	nga1.jpg	nga	nga
57	nga2.jpg	nga	nga
58	nga3.jpg	nga	nga
59	nga4.jpg	ma*	nga
60	nga5.jpg	ma*	nga
61	nya1.jpg	nya	nya
62	nya2.jpg	nya	nya
63	nya3.jpg	nya	nya
64	nya4.jpg	nya	nya
65	nya5.jpg	nya	nya
66	pa1.jpg	pa	pa
67	pa2.jpg	sa*	pa
68	pa3.jpg	pa	pa
69	pa4.jpg	pa	pa
70	pa5.jpg	pa	pa
71	ra1.jpg	ra	ra

72	ra2.jpg	ra	ra
73	ra3.jpg	ra	ra
74	ra4.jpg	ra	ra
75	ra5.jpg	ra	ra
76	sa1.jpg	na*	sa
77	sa2.jpg	dha*	sa
78	sa3.jpg	sa	sa
79	sa4.jpg	ka*	sa
80	sa5.jpg	sa	sa
81	ta1.jpg	ta	ta
82	ta2.jpg	ta	ta
83	ta3.jpg	ta	ta
84	ta4.jpg	ta	ta
85	ta5.jpg	ta	ta
86	tha1.jpg	tha	tha
87	tha2.jpg	tha	tha
88	tha3.jpg	tha	tha
89	tha4.jpg	tha	tha
90	tha5.jpg	tha	tha
91	wa1.jpg	wa	wa
92	wa2.jpg	wa	wa
93	wa3.jpg	wa	wa
94	wa4.jpg	wa	wa
95	wa5.jpg	wa	wa
96	ya1.jpg	ya	ya
97	ya2.jpg	ya	ya
98	ya3.jpg	ya	ya
99	ya4.jpg	ya	ya
100	ya5.jpg	ya	ya

Tabel 5.1 Hasil Penelitian

Pengujian yang dilakukan pada tabel 5.1 diatas dilakukan dengan menggunakan 100 kali pengujian citra dengan masing- masing kategori yakni sebanyak 5 citra uji. Tabel diatas memiliki beberapa kolom diantaranya adalah kolom nama citra uji, yakni label nama citra yang akan diuji, lalu kolom hasil prediksi merupakan hasil uji yang dihasilkan setelah menggunakan metode CNN, dan yang terakhir adalah kolom hasil yang sebenarnya merupakan kolom hasil yang seharusnya ditampilkan pada saat citra tersebut diuji. Berdasarkan hasil pengujian yang telah dilakukan tersebut, dari 100 kali pengujian yang telah dilakukan menghasilkan akurasi memprediksi secara benar adalah sebesar 85%,

dengan tingkat kesalahan dalam memprediksi sebanyak 15 kali atau 15% dari total 100 kali pengujian yang dilakukan.



Grafik 5.1 Grafik Hasil Prediksi Semua Kelompok


Berdasarkan grafik 5.1, ditampilkan grafik hasil prediksi untuk semua kelompok, yakni kelompok 1 adalah HA, NA, CA, RA, KA, lalu kelompok 2 adalah DA, TA, SA, WA, LA, lalu kelompok 3 adalah PA, DHA, JA, YA, NYA, dan kelompok 4 adalah MA, GA, BA, THA, NGA. Berdasarkan grafik tersebut kelompok 1 dan kelompok 3 yang memiliki tingkat akurasi prediksi benar sebesar 92%, sedangkan yang paling terkecil akurasi prediksi secara benar adalah kelompok 2 dengan akurasi 72%. Dan untuk kategori 4 memiliki tingkat akurasi prediksi secara benar adalah 84%.

5.2 Hasil Analisis Penelitian Per Kelompok

5.2.1 Kelompok 1 (HA, NA, CA, RA, KA)

Pada grafik 5.1 berikut merupakan grafik hasil pengujian untuk kelompok 1 yakni HA, NA, CA, RA, KA dengan menggunakan total pengujian adalah sebanyak 25 kali


dengan menggunakan citra 1000 citra pelatihan. Untuk aksara HA, NA, CA, RA menghasilkan tingkat akurasi 100%, sedangkan untuk aksara KA hanya menghasilkan tingkat akurasi prediksi secara benar sebesar 60%.



Grafik 5.2 Grafik Hasil Pengujian Kelompok 1 (HA,NA, CA, RA, KA)

5.2.2 Kelompok 2 (DA, TA, SA, WA, LA)


Pada grafik 5.2 berikut merupakan grafik hasil pengujian untuk kelompok 2 yakni DA, TA, SA, WA, LA dengan menggunakan total pengujian adalah sebanyak 25 kali dengan menggunakan citra 1000 citra pelatihan. Untuk aksara TA, WA, dan LA menghasilkan tingkat akurasi 100%, sedangkan untuk aksara DA hanya menghasilkan akurasi prediksi benar sebesar 20% dan SA hanya menghasilkan tingkat akurasi prediksi secara benar sebesar 40%. Untuk aksara DA berdasarkan hasil prediksi yang telah dilakukan melakukan prediksi yang salah sebesar 80% dengan memprediksi hasilnya adalah aksara NA. Sedangkan aksara SA sebesar 60% menghasilkan prediksi salah dengan hasil prediksinya adalah NA, DHA, dan KA.



Grafik 5.3 Grafik Hasil Pengujian Kelompok 2 (DA, TA, SA, WA, LA)

5.2.3 Kelompok 3 (PA, DHA, JA, YA, NYA)


Pada grafik 5.3 berikut merupakan grafik hasil pengujian untuk kelompok 3 yakni PA, DHA, JA, YA, NYA dengan menggunakan total pengujian adalah sebanyak 25 kali dengan menggunakan citra 1000 citra pelatihan. Untuk aksara DHA, YA, dan NYA menghasilkan tingkat akurasi 100%, sedangkan untuk aksara PA dan JA hanya menghasilkan akurasi prediksi benar sebesar 80%. Untuk aksara PA berdasarkan hasil prediksi yang telah dilakukan melakukan prediksi yang salah sebesar 20% dengan memprediksi hasilnya adalah aksara SA. Sedangkan aksara JA sebesar 20% menghasilkan prediksi salah dengan hasil prediksinya adalah PA.



Grafik 5.4 Grafik Hasil Pengujian Kelompok 2 (PA, DHA, JA, YA, NYA)

5.2.4 Kelompok 4 (MA, GA, BA, THA, NGA)

Pada grafik 5.4 berikut merupakan grafik hasil pengujian untuk kelompok 4 yakni MA, GA, BA, THA, NGA dengan menggunakan total pengujian adalah sebanyak 25 kali dengan menggunakan citra 1000 citra pelatihan. Untuk aksara MA, BA, dan THA menghasilkan tingkat akurasi 100%, sedangkan untuk aksara GA dan NGA hanya menghasilkan akurasi prediksi benar sebesar 60%. Untuk aksara GA berdasarkan hasil prediksi yang telah dilakukan melakukan prediksi yang salah sebesar 40% dengan memprediksi hasilnya adalah aksara PA. Sedangkan aksara NGA sebesar 40% menghasilkan prediksi salah dengan hasil prediksinya adalah MA.



Grafik 5.5 Grafik Hasil Pengujian Kelompok 4 (MA, GA, BA, THA, NGA)

BAB VI. KESIMPULAN DAN SARAN

6.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, maka dapat diambil kesimpulan bahwa pengklasifikasian aksara jawa dengan menggunakan metode Convolutional Neural Network (CNN) menghasilkan tingkat akurasi secara keseluruhan sebesar 85% dengan menggunakan 1000 citra pelatihan dan 100 citra pengujian. Lalu tingkat akurasi jika dilihat secara kelompok aksara jawa, maka dapat diambil kesimpulan bahwa kelompok 1 dan 3 dengan tingkat akurasi adalah sebesar 92%, sedangkan yang paling rendah tingkat akurasinya jika dilihat per kelompok aksara jawa adalah kelompok 2 dengan tingkat akurasi sebesar 72%. Sedangkan jika dilihat dari per aksara jawanya, maka yang memiliki tingkat akurasi paling tinggi adalah aksara HA, NA, CA, RA, TA, WA, LA, DHA, YA, NYA, MA, BA, dan THA dengan memprediksi benar semua, sedangkan aksara DA memiliki tingkat akurasi yang paling rendah karena memiliki tingkat kesalahan tertinggi yakni 4 kali selama memprediksi.

6.2 Saran

Hasil penelitian ini masih perlu dikaji lebih mendalam tentang beberapa kesalahan dalam memprediksi seperti aksara DA dan KA yang dalam memprediksinya hampir selalu menampilkan hasilnya adalah NA dan NGA. Agar nantinya hasil penelitian ini dapat sepenuhnya digunakan untuk pengembangan selanjutnya dalam mengenali rangkaian kalimat dengan menggunakan aksara jawa.

DAFTAR PUSTAKA

- Everingham, M., Van Gool, L., Williams, C.K., Winn, J. and Zisserman, A., The pascal visual object classes (voc) challenge. *International journal of computer vision*, 88(2), pp.303-338.2010
- Fergus, R., & Zeiler, M. D. Visualizing and Understanding Convolutional Networks. *Computer Vision – ECCV. Lecture Notes in Computer Science*, 8689. 2014
- He, K., Zhang, X., Ren, S., & Sun, J. “Deep Residual Learning for Image Recognition”. *IEEE Conference on Computer Vision and Pattern Recognition*.2015
- Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet classification with deep convolutional neural networks." In *Advances in neural information processing systems*, pp. 1097-1105. 2012.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. Gradient-Based Learning Applied to Document Recognition. *Proceedings of the IEEE*, 86(11), 2278 - 2324. 1998
- Lin, T.Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P. and Zitnick, C.L., September. Microsoft coco: Common objects in context. In *European Conference on Computer Vision* (pp. 740-755). Springer International Publishing.2014
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M. and Berg, A.C., 2015. Imagenet large scale visual recognition challenge. *International Journal of Computer Vision*, 115(3), pp.211-252.
- Simonyan, Karen, and Andrew Zisserman. "Very deep convolutional networks for large-scale image recognition." *arXiv preprint arXiv:1409.1556* .2014.
- Srivastava, N., Hinton, G., & Krizhevsky, A. (2014). Dropout: A Simple Way to Prevent Neural Networks from. *Journal of Machine Learning Research*(15), 1929-1958.
- Szegedy, Christian, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, and Andrew Rabinovich. "Going deeper with convolutions." In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1-9. 2015.